



© CC BY Коллектив авторов, 2026  
УДК 616.33/.34-004.8  
<https://doi.org/10.24884/1607-4181-2026-33-1-19-29>

**А. А. Гаранин\*, О. А. Рубаненко, Ю. А. Трусов, А. В. Колсанов**

Самарский государственный медицинский университет  
443099, Россия, г. Самара, ул. Чапаевская, д. 89

## ПРИМЕНЕНИЕ ИСКУССТВЕННОГО ИНТЕЛЛЕКТА ДЛЯ НАБЛЮДЕНИЯ ЗА ПАЦИЕНТАМИ С ЗАБОЛЕВАНИЯМИ ЖЕЛУДОЧНО-КИШЕЧНОГО ТРАКТА: ВОЗМОЖНОСТИ И ОГРАНИЧЕНИЯ

*Поступила в редакцию 05.02.2026 г.; принята к печати 04.03.2026 г.*

### Резюме

**Цель** — анализ источников литературы по вопросам мониторинга и наблюдения пациентов с заболеваниями желудочно-кишечного тракта (ЖКТ) в повседневной врачебной практике с применением методов машинного обучения.

**Методы и материалы.** Для подготовки обзора осуществлялся поиск научных публикаций в таких базах данных, как PubMed, Web of Science, Scopus, CyberLeninka, eLibrary и Google Scholar. Стратегия поиска включала использование ключевых слов на русском и английском языках: «diseases of the gastrointestinal tract», «gastroenterological diseases», «artificial intelligence», «machine learning», «deep learning», «patient monitoring», «remote monitoring», «болезни желудочно-кишечного тракта», «гастроэнтерологические заболевания», «искусственный интеллект», «машинное обучение», «глубокое обучение», «наблюдение за пациентами», «мониторинг». Включение оригинальных исследований в период 2015 – 2025 гг. основано на независимой оценке авторами.

**Результаты.** Из 594 публикаций после скрининга в окончательный анализ включено 9 исследований, отвечающих критериям включения.

**Заключение.** ИИ обеспечивает современные подходы к мониторингу, диагностике и прогнозированию осложнений болезней ЖКТ. Созданные на его основе решения отличаются высокой точностью диагностики и прогнозирования, нередко превосходящей классические клинические шкалы, и формируют фундамент интеллектуальных систем поддержки принятия решений врачами.

**Ключевые слова:** болезни желудочно-кишечного тракта, гастроэнтерологические заболевания, искусственный интеллект, машинное обучение, глубокое обучение, мониторинг, наблюдение

**Для цитирования:** Гаранин А. А., Рубаненко О. А., Трусов Ю. А., Колсанов А. В. Применение искусственного интеллекта для наблюдения за пациентами с заболеваниями желудочно-кишечного тракта: возможности и ограничения. Ученые записки ПСПБГМУ им. акад. И. П. Павлова. 2026; 33(1):19 – 29. <https://doi.org/10.24884/1607-4181-2026-33-1-19-29>.

**Автор для связи:** Андрей Александрович Гаранин, ФГБОУ ВО СамГМУ Минздрава России, 443099, Российская Федерация, г. Самара, ул. Чапаевская, 89. E-mail: [sameagle@yandex.ru](mailto:sameagle@yandex.ru).

**Andrey A. Garanin\*, Olesya A. Rubanenko, Yuri A. Trusov, Alexander V. Kolsanov**

Samara State Medical University  
89, Chapaevskaya str., Samara, Russia, 443099

## THE USE OF ARTIFICIAL INTELLIGENCE FOR MONITORING PATIENTS WITH GASTROINTESTINAL DISEASES: OPPORTUNITIES AND LIMITATIONS

*Received 05.02.2026; accepted 04.03.2026*

### Summary

**The objective** was to analyze the literature sources on monitoring and observation of patients with diseases of the gastrointestinal tract (GIT) in daily medical practice using machine learning methods.

**Methods and materials.** To prepare the review, scientific publications were searched in databases such as PubMed, Web of Science, Scopus, CyberLeninka, eLibrary, and Google Scholar. The search strategy included the use of keywords in Russian and English: «diseases of the gastrointestinal tract», «gastroenterological diseases», «artificial intelligence», «machine learning», «deep learning», «patient monitoring», «remote monitoring». The inclusion of original research in the period 2015 – 2025 is based on an independent assessment by the authors.

**Results.** Of the 594 publications, 9 studies meeting the inclusion criteria were included in the final analysis after screening.

**Conclusion.** AI provides modern approaches to monitoring, diagnosing, and predicting complications of gastrointestinal diseases. The solutions created on its basis are characterized by high diagnostic and forecasting accuracy, often exceeding classical clinical scales, and form the foundation of intelligent decision support systems for doctors.

**Keywords:** diseases of the gastrointestinal tract, gastroenterological diseases, artificial intelligence, machine learning, deep learning, monitoring, observation

**For citation:** Garanin A. A., Rubanenko O. A., Trusov Yu. A., Kolsanov A. V. The use of artificial intelligence for monitoring patients with gastrointestinal diseases: opportunities and limitations. *The Scientific Notes of Pavlov University*. 2026;33(1):19 – 29. (In Russ.). <https://doi.org/10.24884/1607-4181-2026-33-1-19-29>.

\* **Corresponding author:** Andrey A. Garanin, Samara State Medical University, 89, Chapaevskaya str., Samara, Russia, 443099. E-mail: sameagle@yandex.ru.

## ВВЕДЕНИЕ

Заболевания желудочно-кишечного тракта (ЖКТ) представляют собой одну из наиболее распространенных проблем здравоохранения, существенно влияющих на качество жизни населения и экономику стран. Современные подходы к мониторингу пациентов с заболеваниями ЖКТ требуют внедрения инновационных технологий, позволяющих повысить эффективность наблюдения, снизить затраты на лечение и минимизировать риски осложнений.

Одним из перспективных направлений является применение методов искусственного интеллекта (ИИ) для наблюдения и мониторинга состояния пациентов с патологиями органов пищеварения [1]. ИИ способен обрабатывать большие объемы медицинских данных, выявлять скрытые закономерности и формировать индивидуальные прогнозы течения заболевания. Использование ИИ позволяет своевременно обнаруживать изменения в состоянии пациента, предупреждать развитие серьезных осложнений и оптимизировать стратегию лечения [2, 3].

Необходимо учитывать основные ограничения при применении методов и технологий ИИ в гастроэнтерологии — это отсутствие единых стандартов и протоколов оценки результатов, что ограничивает применение новых методик, недостаточное количество структурированных баз данных, что замедляет развитие технологий ИИ.

Поэтому актуальным представляется изучение возможностей применения ИИ для улучшения диагностического процесса и повышения качества медицинской помощи пациентам с заболеваниями пищевода, желудка, кишечника, печени и поджелудочной железы, рассмотрение преимуществ и ограничения современных подходов, а также подготовки практических рекомендаций по внедрению новых технологий в повседневную клиническую практику.

Традиционные модели машинного обучения, такие как «случайный лес» (Random Forest), градиентный бустинг (Gradient Boosting Machines) и логистическая регрессия (Logistic Regression), ши-

роко используются для классификации симптомов и признаков заболеваний ЖКТ [2 – 5]. Они помогают определить риск развития болезни и выбрать оптимальное лечение.

Примеры успешных применений:

– модели Random Forest применяют для выявления предикторов рецидивов гастроэзофагеального рефлюкса;

– Gradient Boosting используется для построения прогностической модели вероятности рака толстой кишки.

Наиболее эффективными моделями глубокого обучения являются сверточные нейронные сети (CNNs) и рекуррентные нейронные сети (RNNs). Эти модели успешно применяются для анализа изображений эндоскопии, колоноскопии и капсульной эндоскопии. Например: CNN-модели способны автоматически распознавать признаки воспалительных процессов, язвенных поражений и опухолей на изображениях слизистой оболочки желудка и кишечника, RNN-модель эффективно обрабатывают временные последовательности данных, что полезно при долгосрочном наблюдении за пациентами с хроническими заболеваниями ЖКТ [6].

**Цель** исследования — анализ источников литературы по вопросам мониторинга и наблюдения пациентов с заболеваниями ЖКТ в повседневной врачебной практике с применением методов машинного обучения.

## МЕТОДЫ И МАТЕРИАЛЫ

**Методология исследования.** Для подготовки обзора осуществлялся поиск научных публикаций в таких базах данных, как PubMed, Web of Science, Scopus, CyberLeninka, eLibrary и Google Scholar. Стратегия поиска включала использование ключевых слов на русском и английском языках: «diseases of the gastrointestinal tract», «gastroenterological diseases», «artificial intelligence», «machine learning», «deep learning», «patient monitoring», «remote monitoring», «болезни желудочно-кишечного тракта», «гастроэнтерологические заболевания», «искусственный интеллект», «машинное

обучение», «глубокое обучение», «наблюдение за пациентами», «мониторинг».

Авторы выполняли отбор исследований, удовлетворяющих установленным критериям включения. Обзор охватывал оригинальные работы, опубликованные на русском и английском языках в период с 2015 по 2025 гг., посвященные ключевым аспектам применения моделей ИИ для наблюдения, прогнозирования и контроля состояния больных гастроэнтерологическими заболеваниями. После завершения процесса отбора в итоговую версию обзора вошли девять исследований (рисунков). Все авторы последовательно изучали аннотации, полные тексты выбранных статей и собирали требуемые данные для составления обзора. Если возникали расхождения относительно включения какой-либо публикации, прибегали к помощи четвертого независимого исследователя, и конечное решение принималось коллегиально.

Исключению подверглись конференции, диссертация, метаанализы, систематические обзоры и руководства, поскольку они зачастую не предоставляют подробностей архитектуры моделей ИИ и сведений о валидации. Ввиду значительного объема первоначального набора статей дублирующиеся публикации были удалены.

Оценка качества исследований традиционными методами (такими как Newcastle-Ottawa Scale или Cochrane Risk of Bias Tool) не производилась, поскольку большинство избранных работ сосредоточено на создании и проверке прогностических моделей, а не на сравнении традиционных клинических групп.

*Анализ данных.* Для каждого включенного исследования была собрана следующая информация: характеристика обследованной группы (численность, средний возраст, половая принадлежность, диагноз), вид используемых данных (эндоскопия, магнитно-резонансная томография, компьютерная томография, гистология, ультразвуковое исследование и прочее), специфика модели ИИ (алгоритм, конструкция нейронной сети, целевое назначение), ключевые итоги и меры точности модели (чувствительность, точность, специфичность, показатель площади под ROC-кривой и прочие).

## РЕЗУЛЬТАТЫ ИССЛЕДОВАНИЯ И ИХ ОБСУЖДЕНИЕ

Блок-схема включенных исследований представлена на рисунке.

Основные характеристики статей, отвечающих критериям включения, представлены в таблице.

Представленный анализ литературных источников говорит о достаточной эффективности методов ИИ в рамках мониторинга и наблюдения за пациентами с болезнями ЖКТ, начиная от выявления осложнений до оптимизации терапии.

В исследовании С. А. Siegel et al. (2016) оценивалось время от постановки диагноза до развития

первого осложнения болезни Крона (БК): стриктурирования, образования внутренних свищей и др., учитывалась потребность в резекции кишечника или в проведении стриктуропластики. Значимыми переменными в многомерной модели Кокса были заболевания тонкой кишки (относительный риск (ОР) 2,12, доверительный интервал (ДИ) 1,05–4,29), левой части толстой кишки (ОР 0,73, ДИ 0,49–1,09), перианальные заболевания (ОР 4,12, ДИ 1,01–16,88), ASCA (антитела к *Saccharomyces cerevisiae*) (ОР 1,35, ДИ 1,16–1,58), Cbir (Computer-Based Interactive Review, метод оценки выраженности заболевания) (ОР 1,29, ДИ 1,07–1,55), ANCA (антинейтрофильные цитоплазматические антитела) (ОР 0,77, ДИ 0,62–0,95) и мутация сдвига рамки NOD2/SNP13 (ОР 2,13, ДИ 1,33–3,40) [7].

Y. Park et al. (2017) показал, что за период наблюдения, который составил 10 188 пациенто-лет (медиана 7,1 года), 361 пациент (28,4 %) перенес операцию, связанную с БК. Возраст на момент постановки диагноза, поражение тощей кишки, начальный характер заболевания и перианальные заболевания на момент постановки диагноза были связаны с неблагоприятным прогнозом и включены в модель KCDP (Korean Crohn's Disease Prediction), которая показала умеренную способность к распознаванию с-индекса Харрела, равного 0,731, через 5 лет и была хорошо откалибрована (Хосмер – Лемешоу  $\chi=8,230$ ,  $P=0,511$ ). По результатам исследования создана шкала S-KCDP Classification (Simplified Korean Crohn's Disease Prediction), где низкий риск 0–1, умеренный риск 1,5–2, высокий 2,5 [8].

N. Khan et al. (2017) продемонстрировал, что 288 пациентам (41,2 %) для лечения язвенного колита (ЯК) потребовалась терапия кортикостероидами. Ключевыми факторами, влияющими на необходимость проведения данной терапии, выбранными для модели, были следующие: возраст, неафроамериканское происхождение, наличие гипоальбуминемии и железодефицитной анемии на момент постановки диагноза «язвенный колит», эндоскопическая степень или тяжесть заболевания на момент проведения индексной колоноскопии. Модель распознавания работала хорошо (точность предсказания составила около 71 %, с вероятностью 95 %), независимо от того, учитывалась первоначальная тяжесть заболевания или нет. Точность калибровки также оставалась стабильно высокой во всех вариантах моделей (статистически значимых отклонений не обнаружено). Результаты моделирования были схожими и при проверке внутри выборочной группы [9].

M. Cesarini et al. (2017) в своем исследовании поставил цель выявления прогностических факторов развития ЯК в течение 3-летнего периода с момента постановки диагноза острого колита, создание простого показателя, который можно было бы применять в клинической практике, с последующей



Рис. 1. Алгоритм отбора публикаций для написания систематического обзора

Fig. 1. The algorithm for selecting publications for writing a systematic review

валидацией на двух независимых группах пациентов. Автор отметил, что острый колит развился в среднем за 14 месяцев [диапазон 1 – 29]. В окончательной модели применялась сумма в 1 балл за каждое распространенное заболевание, уровень С-реактивного белка >10 мг/л или гемоглобина <12 г/дл у женщин или <14 г/дл у мужчин на момент постановки диагноза (общая оценка от 0/3 до 3/3). Это предсказывало 70 %-й риск развития заболевания в течение 3 лет [оценка 3/3]. В ходе валидации были выбраны разные группы пациентов с острым колитом. Из тех, кто набрал 3/3 баллов при постановке диагноза, впоследствии развился колит. Внутренняя валидация показала хорошую калибровку с аналогичным прогнозируемым риском для всех когорт. Созданная номограмма позволила предсказывать индивидуальный риск [10].

В работе Ю. П. Успенского и др. (2023) изучались осложнения (декомпенсированная стриктура кишки, кишечное кровотечение, требующее гемотрансфузии, перфорация кишки, развитие колоректального рака, абсцесс брюшной полости, токсическая дилатация кишки, сочетание жизнеугрожающих осложнений (перфорация и декомпенсированная стриктура кишки, токсическая дилатация кишки и кровотечение, перфорация и дилатация кишки, перфорация и рак/дисплазия кишки, стриктура и кишечное кровотечение)) в ходе наблюдения за

пациентами с воспалительными заболеваниями кишечника (ВЗК). Математическое моделирование развития жизнеугрожающих осложнений у пациентов проводилось с использованием трех различных методов. Логистический регрессионный анализ обеспечивал оценку влияния любых типов переменных-предикторов (количественных либо качественных) на зависимую переменную, что позволяло спрогнозировать принадлежность рассматриваемого случая к одной из двух категорий исходя из известных значений предикторов. Аналогично решались задачи прогнозирования категориальных признаков с помощью деревьев классификации, предназначенных для разделения объектов на классы. Применялись нейронные сети из области ИИ, так как обладают способностью к обучению. Программа «Прогноз ВЗК: риск жизнеугрожающих осложнений» продемонстрировала высокий риск — вероятность возникновения от 52 % до 76 %, низкий риск — вероятность не развития от 94 % до 99 %. Программа «Прогноз ВЗК: риск urgentных хирургических осложнений» показала, что высокий риск — вероятность возникновения от 60 % до 87 %, низкий риск — вероятность не развития от 97 % до 100 %. Авторы приходят к выводу, что созданные программы подходят для повседневной клинической работы врачей-гастроэнтерологов, терапевтов и семейных врачей. Они

Характеристика исследований  
Characteristics of the researches

Автор исследования (год)	Размер выборки патологии/срок наблюдения	Возраст (лет)	Пол (М/Ж)	Название способа	Вид ИИ	Характеристика модели	Сравнение с контрольной группой
Ю. П. Успенский и др. (2023) [3]	291 пациент (139 (48 %) БК, 152 (52 %) ЯК)/ 3 года	36 (26; 51): БК 34 (26; 50) ЯК 37 (27; 53)	М 136 (46,7 %) Ж 155 (53,3 %)	1. Логистическая регрессия 2. Построение деревьев классификации 3. Построение нейронных сетей	Нейронные сети	2 компьютерные программы «Прогноз ВЗК – риск жизнеугрожающих осложнений» и «Прогноз ВЗК: риск urgentных хирургических осложнений»	Первая программа: чувствительность 84,8 % (71,8 – 92,4), специфичность 91,4 % (87,3 – 94,3), точность 90,4 % (86,5 – 93,3). Вторая программа: чувствительность 92,3 % (75,9 – 97,9), специфичность 92,3 % (75,9 – 97,9), точность 96,9 % (94,2 – 98,4)
С. А. Siegel et al. (2016) [7]	243 пац. БК /3 года	24,8 (10,5–52,0)	Не указано	Многомерная модель Кокса	Регрессионная модель выживаемости	Коэффициент Харрелла С (индекс соответствия для прогнозной точности модели) = 0,73	При применении к двум когортам внешней валидации (взрослые n = 109, педиатрические n = 392) индекс соответствия составил 0,73 и 0,75 соответственно для взрослых и педиатрических пациентов
Y. Park et al. (2017) [8]	1338 пациент БК/ 7,1 лет (10188 пациенто-лет)	24,0 (7 – 87)	М 882 (69,4 %)	Модель пропорциональных рисков Кокса с многомерным анализом	Регрессионная модель выживаемости	Умеренная способность к распознаванию с-индекса Харрелла, равного 0,731, через 5 лет	Хорошо откалибрована (Хосмер-Лемешоу $\chi = 8,230$ , $P = 0,511$ )
N. Khan et al. (2017) [9]	699 пациентов ЯК/ 8 лет	Не указан	Не указан	Мультиномиальная логистическая регрессионная модель	Многофакторная модель	ROC-AUC 0,71 [95 % ДИ 0,66-0,76] для модели, включающей исходную степень ЯК, 0,71 [95 % ДИ 0,67-0,76] для модели, включающей исходную степень тяжести ЯК	Калибровка моделей была стабильно хорошей во всех моделях (достоверность соответствия по шкале Хосмера-Лемеша $p > 0,05$ ). Модели показали аналогичные результаты в группе внутренней валидации
M. Cesarini et al. (2017) [10]	111 пациент с острым колитом/ 14 месяцев	16 – 89 лет	М от 15 (44 %) до 44 (62 %)	Мультиномиальная логистическая регрессионная модель	Многофакторная модель	70 %-й риск развития болезни в течение 3 лет (оценка 3/3). Валидация: (Cambridge = 25/96; Uppsala = 18/298). Из тех, кто набрал 3/3 баллов при постановке диагноза, у 18/18 (Cambridge) и 12/13 (Uppsala) впоследствии развился колит	Дискриминантная способность [с-индекс, где 1,0 = совершенная дискриминация] составила 0,81 (Oxford), 0,95 (Cambridge), 0,97 (Uppsala). Внутренняя проверка с использованием bootstrapping показала хорошую калибровку с аналогичным прогнозируемым риском для всех когорт. Нограмма предсказывала индивидуальный риск

Продолжение таблицы  
Continuation of table

Автор исследования (год)	Размер выборки патологии/срок наблюдения	Возраст (лет)	Пол (М/Ж)	Название способа	Вид ИИ	Характеристика модели	Сравнение с контрольной группой
K. N. Fockens et al. (2023) [11]	2506 пациентов/неоплазия пищевода Барретта и недиспластическая форма пищевода Барретта	Не указан	Не указан	Модель логистической регрессии со смешанными эффектами и словесными коэффициентами вероятности	Система CADe была сначала предварительно обучена с помощью ImageNet, а затем с помощью GastroNet	Se выявления неоплазии среди эндоскопистов увеличилась с 74 % до 88 % с помощью CADe (или 2,04; 95 % ДИ 1,73 – 2,42; $p < 0,0001$ для изображений и с 67 % до 79 % [2,35; 1,90 – 2,94; $p < 0,0001$ ] для видео) без снижения Sp (с 89 % до 90 % [1,07; 0,96 – 1,19; $p = 0,20$ ] для изображений и с 96 % до 94 % [0,94; 0,79 – 1,11] для видео; $p = 0,46$ ). В тестовом наборе CADe выявил опухолевые поражения на 95 % (88 – 98) снимках и 97 % (90 – 99) видеозаписях	Система CADe превзошла эндоскопистов в выявлении неоплазии (90 % против 74 % [или 3,75; 95 % ДИ 1,93 – 8,05; $p = 0,0002$ ] для изображений и 91 % против 67 % [1,68; 3,85 – 47,53; $p < 0,0001$ ] для видео) и не уступает экспертам по пищеводу Барретта (90 % против 87 % [ИЛИ 1,74; 95 % ДИ 0,83 – 3,65] для изображений и 91 % против 86 % [2,94; 0,99 – 11,40] для видео).
van E. J. R. Beek et al. (2023) [12]	483 пациента/портальная гипертензия вследствие вирусного гепатита В и спленэктомия	Старше 18 лет	М от 20 (25,0 %) до 69 (34,0 %) Ж от 134 (66,0 %) до 60 (75,0 %)	Обобщенный линейный метод (GL), метод машинного обучения и статистики для выбора признаков и регуляризации (LASSO) и случайный лес (RF)	Методы машинного обучения	ROC-кривые GL, LASSO и RF в обучающей когорте составили 0,83 (95 % ДИ: 0,79 – 0,88), 0,84 (95 % ДИ: 0,79 – 0,88) и 0,84 (95 % ДИ: 0,79 – 0,88) соответственно; и составили 0,77 (95 % ДИ: 0,69 – 0,85), 0,83 (95 % ДИ: 0,76 – 0,90) и 0,78 (95 % ДИ: 0,70 – 0,85) в группе валидации соответственно	Калибровочные кривые показали удовлетворительное соответствие между прогнозом с помощью моделей и фактическим наблюдением
M. Jiang et al. (2025) [13]	2008 – 2019 257 366 пациентов, 2014 – 2015 139 367 пациентов/острый панкреатит	От 52,0 (41,0, 63,0) лет до 67,1 (55,3, 80,0) лет	М от 140 (56,0 %) до 20 (58,8 %)	Модель машинного обучения с ускорением градиента (XGBoost)	Методы машинного обучения	AUC 0,89 (95 % ДИ: 0,84 – 0,94), чувствительность на 100 % специфичность 38 %	Модель XGBoost показала лучшие результаты прогнозирования риска смертности у пациентов с острым панкреатитом, чем системы клинической оценки, в частности, чем показатели APACHE IV, SOFA и BISAP, которые имели специфичность 1 %, 16 % и 1 % соответственно

Окончание таблицы  
End of table

Автор исследования (год)	Размер выборки патологии/срок наблюдения	Возраст (лет)	Пол (М/Ж)	Название способа	Вид ИИ	Характеристика модели	Сравнение с контрольной группой
J. M. Kim et al. (2024)	198 пациент/ дисфагия	40 лет и старше 72,30±12,03	М 52 (74,29 %) Ж 18 (25,71 %)	Многослойный пер-септрон (MLP) с MobileNet V3	Методы машинного обучения	Обученные модели (mn40_as, mn30_as). Модель mn30_as: комбина-рованная модель 0,8361 (95 % ДИ 0,7667-0,9056; макс.0,9541), модель для мужчин – 0,8010 (95 % ДИ 0,6589 – 0,9432; мак-симум 1000) и модель для женщин – 0,7572 (95 % ДИ 0,6578-0,8567; максимум 0,99779). Модели mn4.0 у женщин 0,7679 балла (95 % ДИ 0,6426 – 0,8931; максимальное значение 0,9722)	Точность прогнозирования моделей выше 0,7, наиболь-шая точность прогнозиро-вания при складывании для большинства моделей (пре-дварительная модель mn40_as, обученная модель mn30_as, модель без предваритель-ного обучения mn4.0, пред-варительная модель mn30_as, модель без предваритель-ного обучения mn3.0) 0,9

помогают предсказывать возникновение опасных осложнений у пациентов с ВЗК, основываясь на особенностях течения болезни, демографической информации и характере применяемой специфической терапии [3].

В гастроэнтерологии системы автоматизированного обнаружения (CADe) могут помочь эндоскопистам в выявлении ранней неоплазии пищевода Барретта, которую может быть трудно обнаружить на эндоскопических изображениях. Поэтому в исследовании K. N. Fockens et al. (2023) система CADe была сначала предварительно обучена с помощью ImageNet, а затем с помощью GastroNet на наборе данных из 14 046 изображений (2506 пациентов) с подтвержденной неоплазией пищевода Барретта и недиспластической формой пищевода Барретта из 15 центров. Неоплазия была выявлена 14 экспертами Barrett's oesophagus по всем наборам данных. Эффективность системы CADe анализировалась на двух независимых наборах тестов. Набор тестов включал 327 (73 пациента) изображений пищевода Барретта, не связанных с дисплазией, 82 (46 пациентов) изображения опухолей, 180 (66 из тех же пациентов) видеозаписей пищевода Барретта, не связанных с дисплазией, и 71 (45 из тех же пациентов) видеозаписи опухолей. Набор сравнительных тестов состоял из 100 (50 пациентов) изображений опухолей, 300 (125 пациентов) изображений без диспластических изменений, 47 (47 из тех же пациентов) видеороликов с опухолями и 141 (82 из тех же пациентов) видеороликов без диспластических изменений и был дополнен случаями малозаметной неоплазии. Набор контрольных тестов был оценен 112 эндоскопистами из шести стран (сначала без CADe, а через 6 недель с CADe) и 28 внешними международными экспертами по пищеводу Барретта. Основные результаты включали увеличение чувствительности к обнаружению неоплазии среди эндоскопистов (для изображений и для видео) без снижения специфичности. В ходе сравнительного тестирования система CADe превзошла эндоскопистов в выявлении неоплазии (для изображений и для видео) и не уступает экспертам по пищеводу Барретта [11].

J. Li et al. (2022) оценивал значение скорости повышения уровня тромбоцитов в послеоперационном периоде (PPER) при проведении спленэктомии для прогнозирования риска тромбоза портальной вены (ПВТ) у пациентов с портальной гипертензией. Многофакторный анализ показал, что первые и третьи сутки PPER (PPER1, PPER3) были тесно связаны с развитием ПВТ [отношение шансов (ОШ): 1,78, 95 % ДИ: 1,24 – 2,62, p = 0,002; ОШ: 1,43, 95 % ДИ: 1,16 – 1,77, p = 0,002 < 0,001 соответственно]. PPER1 и PPER3 являются эффективными показателями для прогнозирования развития ПВТ в послеоперационном периоде [12].

M. Jiang et al. (2025) показал, что существующие модели прогнозирования являются неоптимальны-

ми для определения риска смертности у пациентов с острым панкреатитом (ОП); это может быть улучшено с помощью модели машинного обучения. В исследовании авторы разработали и апробировали модель для расчета риска смертности у пациентов с ОП, поступивших в отделение интенсивной терапии, и сравнили ее с существующими системами оценки. Эффективность модели XGBoost сопоставляли с проверенными клиническими системами оценки риска (APACHE IV, SOFA и Bedside Index для определения тяжести острого панкреатита [BISAP]) по площади под кривой рабочих характеристик приемника (AUC). Для объяснения результатов прогнозирования был применен метод SHAP (SHapley Additive exPlanations). Авторы показали, что модель может помочь в выявлении пациентов с очень низким уровнем риска, которые могут безопасно наблюдаться в стационаре [13].

Одним из аспектов, который изучается в гастроэнтерологии, является оценка дисфагии на основе голоса. J. M. Kim et al. (2024), основываясь на гипотезе о влиянии ослабленной мышечной силы и наличия аспирации на голосовые характеристики, провел одноцентровое проспективное исследование с разработкой алгоритма прогнозирования состояния дисфагии (в норме и при аспирации) путем анализа голоса после приема пищи, ограничивающего потребление до 3 см<sup>3</sup>. Представленные модели (предварительно обученные; mn40\_as, без предварительного обучения; mn4.0 и mn3.0) (буква «mn» в названиях моделей относится к MobileNet, следующая цифра указывает на параметр «width\_mult») достигли точность прогнозирования (с учетом метрик качества: точность, чувствительность, специфичность, прогностическая ценность, показатель F1-score) выше 0,7 в большинстве случаев, а наибольшая точность прогнозирования при складывании для большинства моделей (предобученная модель mn40\_as, модель без предварительного обучения mn4.0, предобученная модель mn30\_as, модель без предварительного обучения mn3.0) составляла примерно около 0,9. Таким образом, анализ mel-спектрограммы и модель MobileNetV3 для прогнозирования дисфагии включает неинвазивные, более безопасные и эффективные вмешательства [14].

Настоящий систематический обзор позволит получить представление о широте имеющихся фактических данных об использовании ИИ в контексте методов визуализации и эндоскопии для диагностики, последующего наблюдения и прогнозирования заболеваний ЖКТ [15]. Это даст возможность обнаружить перспективные направления, которые пока остаются неизученными. Сегодня недостаточно сведений о непосредственном применении ИИ в условиях реальной клинической практики. Именно поэтому будущие исследования позволят восполнить существующие пробелы в научной литературе.

Указанные работы демонстрируют широкий спектр возможностей и проблем, возникающих при внедрении методов ИИ во время мониторинга и наблюдения за пациентами с заболеваниями ЖКТ. Как видно из представленного обзора, подавляющее большинство исследований посвящено ведению больных с ВЗК.

Важными аспектами применения ИИ является выявление ключевых факторов риска и прогнозирование осложнений. Подчеркивается значимость поражения определенных участков кишечника и иммунологических маркеров в развитии осложнений болезни Крона. Эти факторы оказались ключевыми для построения эффективной прогностической модели, которая позволяет заранее планировать тактику ведения пациентов. Подобный подход особенно важен для раннего начала специализированной терапии и предотвращения тяжелых форм заболевания. Учитывается важность сочетания нескольких клинических факторов, таких как поражение тонкого кишечника и перианальные заболевания, для точного прогнозирования хирургического вмешательства у пациентов с болезнью Крона. Предложенная модель демонстрирует высокую прогностическую силу и стабильность, подчеркивая преимущества персонализированной медицины. Подтверждается роль стандартных лабораторных показателей и общего состояния пациента в оценке потребности в кортикостероидной терапии при язвенном колите. Разработанная модель обладает высоким уровнем точности и может использоваться в рутинной клинической практике для оптимизации лечебных стратегий. В другом исследовании предлагается простой инструмент оценки риска перехода острого колита в хронический процесс. Полученная шкала удобна для практического применения и позволяет быстро оценить вероятность неблагоприятных исходов. Есть две прогностические программы («Прогноз ВЗК») для оценки риска серьезных осложнений и экстренных хирургических вмешательств у пациентов с ВЗК. Высокая точность полученных моделей делает их полезными инструментами для принятия клинических решений и планирования профилактических мероприятий.

Следующим положительным моментом является применение компьютерных технологий в эндоскопии. Система автоматического обнаружения (CADe) значительно повысила чувствительность эндоскопистов в обнаружении неоплазии пищевода Барретта. Этот инструмент обещает революционизировать подход к скринингу и профилактике онкологических заболеваний ЖКТ.

Определяющей стороной рассматривается прогнозирование сосудистых осложнений и смертности. Демонстрируется потенциальная польза измерения скорости роста тромбоцитов после операции спленэктомии для прогнозирования риска тромбоза воротной вены. Эти данные важны для

клиницистов, поскольку предоставляют дополнительный маркер для оценки послеоперационного риска. Иллюстрируется возможность современных методов машинного обучения в прогнозировании рисков смерти у пациентов с тяжелым течением острого панкреатита. Показано, что использование метода XGBoost превосходит традиционные клинические шкалы оценки риска, такие как APACHE IV и BISAP.

Оценка дисфагии и аспирации проводится на основе анализа голосовых сигналов после еды. Разработка и тестирование такого подхода открывают новые перспективы для неинвазивной диагностики нарушений глотания, позволяя минимизировать дискомфорт для пациентов и ускорить постановку диагноза.

Несмотря на то, что использование ИИ растет во многих областях медицины и за ее пределами, существуют потенциальные проблемы, связанные с его использованием, которые трудно оценить в литературе, поскольку эта технология продолжает развиваться. Особенно трудно понять, как эта технология может повлиять на врачей, которые не знакомы с последними достижениями в лечении заболеваний ЖКТ. Во-первых, возникают некоторые опасения по поводу ошибочного диагноза, который может возникнуть в контексте ИИ, опирающегося на введенный алгоритм, который может не быть всеобъемлющим и не отражать вариации проявлений у разных групп населения. Во-вторых, может возникнуть неадекватная оценка тяжести заболевания, поскольку для этого требуется детальное понимание различных факторов, включая клинические симптомы, результаты лабораторных исследований, результаты эндоскопии и историю болезни пациента. Врачи, не обладающие глубокими знаниями в области гастроэнтерологии, могут не в полной мере оценить сложность этих факторов, что может привести к неточной оценке тяжести заболевания и неоптимальным решениям о тактике лечения. В-третьих, хотя современные алгоритмы ИИ могут давать рекомендации, основанные на обобщенных данных или рекомендациях, лечение заболеваний желудка или кишечника часто требует индивидуального подхода. Кроме того, поскольку доступно все больше методов лечения заболеваний ЖКТ, требуется проверка, чтобы убедиться, что эти варианты представлены в алгоритмах, обеспечивающих вывод данных ИИ. Врачи, которые не знакомы с этими обновлениями и новейшими продуктами, могут чрезмерно полагаться на ИИ, упуская из виду характеристики пациента, которые могут быть важны при выборе лечения, или не замечая отсутствия новых методов лечения. В-четвертых, алгоритмы ИИ или информационные панели могут не учитывать сложную взаимосвязь между образом жизни, предпочтениями и ценностями пациентов, которая необходима для обеспечения целостного подхода к принятию

управленческих решений, ориентированного на интересы пациента. Наконец, при создании ИИ возникает этическая дилемма, поскольку теперь мы знаем, что некоторые предубеждения и стереотипы были непреднамеренно внедрены в алгоритмы ИИ на основе данных, доступных на этапах машинного обучения. Врачи, которым не хватает глубоких знаний и профессиональной подготовки в области эндоскопии и диагностики заболеваний ЖКТ и их осложнений, могут непреднамеренно усугубить предвзятость или неравенство в оказании медицинской помощи, если используемые ими алгоритмы ИИ не будут надлежащим образом проверены и протестированы в различных группах населения. Кроме того, потенциальная чрезмерная зависимость от систем ИИ без критического мышления и надзора вызывает опасения по поводу ответственности и подотчетности за результаты лечения пациентов.

## ЗАКЛЮЧЕНИЕ

ИИ может существенно повысить эффективность наблюдения и контроля за состоянием больных с патологиями желудочно-кишечного тракта. Тем не менее, внедрение этих технологий должно осуществляться осторожно, учитывая возможные риски и негативные последствия. Для успешной интеграции ИИ необходима тесная совместная работа разработчиков алгоритмов машинного обучения, гастроэнтерологов, эндоскопистов и врачей, знакомых с принципами работы интеллектуальных систем. Только таким образом удастся создать надежные и точные системы, дополняющие знания и опыт квалифицированного медицинского персонала.

## Конфликт интересов

Автор заявил об отсутствии конфликта интересов.

## Conflict of interest

Author declares no conflict of interest.

## Соответствие нормам этики

Автор подтверждает, что соблюдены права людей, принимавших участие в исследовании, включая получение информированного согласия в тех случаях, когда оно необходимо, и правила обращения с животными в случаях их использования в работе. Подробная информация содержится в Правилах для авторов.

## Compliance with ethical principles

The author confirms that they respect the rights of the people participated in the study, including obtaining informed consent when it is necessary, and the rules of treatment of animals when they are used in the study. Author Guidelines contains the detailed information.

## Вклад авторов

А. А. Гаранин — разработка концепции и планирование исследования; О. А. Рубаненко — сбор, анализ и интерпретация данных, написание первоначального текста статьи; Ю. А. Трусов — сбор, анализ и интерпретация

данных; А. В. Колсанов — утверждение окончательной версии статьи.

#### Author contributions

A. A. Garanin — developing the concept and planning the research; O. A. Rubanenko — collecting, analyzing and interpreting the data, writing the initial text of the article; Yu. A. Trusov — collecting, analyzing and interpreting the data; A. V. Kolsanov — approving the final version of the article.

#### ЛИТЕРАТУРА

1. Курбацкий С. М. Нужен ли гастроэнтерологам искусственный интеллект? // Российский журнал гастроэнтерологии, гепатологии, колопроктологии. — 2021. — Т. 31, № 6. — С. 103–105.

2. Кобринский Б. А., Хавкин А. И., Волюнец Г. В. Перспективы применения систем искусственного интеллекта в гастроэнтерологии // Экспериментальная и клиническая гастроэнтерология. — 2020. — Т. 179, № 7. — С. 109–117.

3. Успенский Ю. П., Иванов С. В., Фоминых Ю. А. и др. Прогнозирование развития жизнеугрожающих осложнений воспалительных заболеваний кишечника с использованием нейронных сетей: инструменты для практического здравоохранения // Экспериментальная и клиническая гастроэнтерология. — 2023. — Т. 217, № 9. — С. 20–33. <https://doi.org/10.31146/1682-8658-ecg-217-9-20-33>.

4. Барышникова Н. В., Щапков Н. А. Инновации в гастроэнтерологии // Медицинский алфавит. 2025;(25):8–12. <https://doi.org/10.33667/2078-5631-2025-25-8-12>.

5. Чурилова Е. Г., Казумова А. Б., Ахриева Х. М. и др. Возможности использования технологий искусственного интеллекта в морфологической диагностике воспалительных заболеваний кишечника (обзор литературы) // Вестник медицинского института «РЕАВИЗ». Реабилитация, Врач и Здоровье. — 2025. — Т. 15, № 1. — С. 22–29. <https://doi.org/10.20340/vmi-rvz.2025.1.MORPH.1>.

6. Бакулин И. Г., Расмагина И. А., Скалинская М. И. и др. Применение искусственного интеллекта для анализа эндоскопических изображений при воспалительных заболеваниях кишечника // Терапия. — 2022. — Т. 8, № 599. — С. 7–14. <https://doi.org/10.18565/therapy.2022.7.7-14>.

7. Siegel C. A., Horton H., Siegel L. S. et al. A validated webbased tool to display individualized Crohn’s disease predicted outcomes based on clinical, serologic and genetic variables // Aliment Pharmacol Ther. — 2016. — Т. 43, № 2. — С. 262–71. <https://doi.org/10.1111/apt.13460>.

8. Park Y., Cheon J. H., Park Y. L., Ye B. D. et al. IBD Study Group of the Korean Association for the Study of Intestinal Diseases (KASID). Development of a Novel Predictive Model for the Clinical Course of Crohn’s Disease: Results from the CONNECT Study // Inflamm Bowel Dis. — 2017. — Vol. 23, № 7. — P. 1071–1079. <https://doi.org/10.1097/MIB.0000000000001106>.

9. Khan N., Patel D., Shah Y. et al. A Novel User-Friendly Model to Predict Corticosteroid Utilization in Newly Diagnosed Patients with Ulcerative Colitis // Inflamm Bowel Dis. — 2017. — Vol. 23, № 6. — P. 991–997. <https://doi.org/10.1097/MIB.0000000000001080>.

10. Cesarini M., Collins G. S., Ronnblom A. et al. Predicting the individual risk of acute severe colitis at diagnosis // J Crohns Colitis. — 2017. — Vol. 11, № 3. — P. 335–341. <https://doi.org/10.1093/ecco-jcc/jjw159>.

11. Fockens K. N., Jong M. R., Jukema J. B. et al. A deep learning system for detection of early Barrett’s neoplasia: a model development and validation study // Lancet Digit Health. — 2023. — Vol. 5, № 12. — P. e905–e916. [https://doi.org/10.1016/S2589-7500\(23\)00199-1](https://doi.org/10.1016/S2589-7500(23)00199-1). PMID: 38000874.

12. Li J., Wu Q. Q., Zhu R. H., Lv X. et al. Machine learning predicts portal vein thrombosis after splenectomy in patients with portal hypertension: Comparative analysis of three practical models // World J Gastroenterol. — 2022. — Vol. 28, № 32. — P. 4681–4697. <https://doi.org/10.3748/wjg.v28.i32.4681>.

13. Jiang M., Wu X. P., Lin X. C., Li C. L. Explainable machine learning model for predicting acute pancreatitis mortality in the intensive care unit // BMC Gastroenterol. — 2025. — Vol. 25, № 1. — P. 131. <https://doi.org/10.1186/s12984-024-01329-6>. PMID: 40033198; PMCID: PMC11877909.

14. Kim J. M., Kim M. S., Choi S. Y., Ryu J. S. Prediction of dysphagia aspiration through machine learning-based analysis of patients’ postprandial voices // J Neuroeng Rehabil. — 2024. — Vol. 21, № 1. — P. 43. <https://doi.org/10.1186/s12984-024-01329-6>. PMID: 38555417; PMCID: PMC10981344.

15. Chavannes M., Kysh L., Allocca M. et al. Role of artificial intelligence in imaging and endoscopy for the diagnosis, monitoring and prognostication of inflammatory bowel disease: a scoping review protocol // BMJ Open Gastroenterol. — 2023. — Vol. 10, № 1. — P. e001182. <https://doi.org/10.1136/bmjgast-2023-001182>. PMID: 38081777; PMCID: PMC10729253.

#### REFERENCES

1. Kurbatsky S. M. Does Gastroenterology Need Artificial Intelligence? // Russian Journal of Gastroenterology, Hepatology, Coloproctology. 2021;31(6):103–105. <https://doi.org/10.22416/1382-4376-2021-31-6-103-105>. (In Russ.).

2. Kobrinskii B. A., Khavkin A. I., Volynets G. V. Prospects for the use of artificial intelligence systems in gastroenterology // Experimental and Clinical Gastroenterology. 2020;179(7):109–117. <https://doi.org/10.31146/1682-8658-ecg-179-7-109-117>. (In Russ.).

3. Uspenskiy Yu. P., Ivanov S. V., Fominykh Yu. A. et al. Prediction of life-threatening complications of inflammatory bowel disease using neural networks: a practical tool for health care professionals // Experimental and Clinical Gastroenterology. 2023;(9):20–33. (In Russ.). <https://doi.org/10.31146/1682-8658-ecg-217-9-20-33>.

4. Baryshnikova N. V., Shchapkov N. A. Innovations in gastroenterology. Medical alphabet. 2025;(25):8–12. (In Russ.).

5. Churilova E. G., Kazumova A. B., Akhrieva Kh. M. et al. Possibilities of using artificial intelligence technologies in the morphological diagnosis of inflammatory bowel diseases (literature review) // Bulletin of the Medical Institute “REAVIZ” (REHABILITATION, DOCTOR AND HEALTH). 2025;15(1):22–29. (In Russ.).

6. Bakulin I. G., Rasmagina I. A., Skalinskaya M. I. et al. The use of artificial intelligence for the analysis of endoscopic images in inflammatory bowel diseases // Therapy. 2022;8(599):7–14. (In Russ.). <https://doi.org/10.18565/therapy.2022.7.7-14>.

7. Siegel C. A., Horton H., Siegel L. S. et al. A validated webbased tool to display individualized Crohn’s disease predicted outcomes based on clinical, serologic and genetic variables // Aliment Pharmacol Ther. 2016;43(2):262–71. <https://doi.org/10.1111/apt.13460>.

8. Park Y., Cheon J. H., Park Y. L. et al. IBD Study Group of the Korean Association for the Study of Intestinal Diseases (KASID). Development of a Novel Predictive Model for the Clinical Course of Crohn’s Disease: Results from the CONNECT Study // Inflamm Bowel Dis. 2017;23(7):1071–1079. <https://doi.org/10.1097/MIB.0000000000001106>.

9. Khan N., Patel D., Shah Y. et al. A Novel User-Friendly Model to Predict Corticosteroid Utilization in Newly Diagnosed Patients with Ulcerative Colitis // Inflamm Bowel Dis. 2017;23(6):991–997. <https://doi.org/10.1097/MIB.0000000000001080>.

10. Cesarini M., Collins G. S., Ronnblom A. et al. Predicting the individual risk of acute severe colitis at diagnosis // J

Crohns Colitis. 2017;11(3):335–341. <https://doi.org/10.1093/ecco-jcc/ijw159>.

11. Fockens K. N., Jong M. R., Jukema J. B. et al. A deep learning system for detection of early Barrett's neoplasia: a model development and validation study // *Lancet Digit Health*. 2023;5(12):e905–e916. [https://doi.org/10.1016/S2589-7500\(23\)00199-1](https://doi.org/10.1016/S2589-7500(23)00199-1). PMID: 38000874.

12. Li J., Wu Q. Q., Zhu R. H. et al. Machine learning predicts portal vein thrombosis after splenectomy in patients with portal hypertension: Comparative analysis of three practical models // *World J Gastroenterol*. 2022;28(32):4681–4697. <https://doi.org/10.3748/wjg.v28.i32.4681>.

13. Jiang M., Wu X. P., Lin X. C., Li C. L. Explainable machine learning model for predicting acute pancreatitis

mortality in the intensive care unit // *BMC Gastroenterol*. 2025;25(1):131. <https://doi.org/10.1186/s12876-025-03723-3>. PMID: 40033198; PMCID: PMC11877909.

14. Kim J. M., Kim M. S., Choi S. Y., Ryu J. S. Prediction of dysphagia aspiration through machine learning-based analysis of patients' postprandial voices // *J Neuroeng Rehabil*. 2024;21(1):43. <https://doi.org/10.1186/s12984-024-01329-6>. PMID: 38555417; PMCID: PMC10981344.

15. Chavannes M., Kysh L., Allocca M. et al. Role of artificial intelligence in imaging and endoscopy for the diagnosis, monitoring and prognostication of inflammatory bowel disease: a scoping review protocol // *BMJ Open Gastroenterol*. 2023;10(1):e001182. <https://doi.org/10.1136/bmj-gast-2023-001182>. PMID: 38081777; PMCID: PMC10729253.

### Информация об авторах

**Гаранин Андрей Александрович**, кандидат медицинских наук, доцент, директор научно-практического центра дистанционной медицины, Самарский государственный медицинский университет (г. Самара, Россия), ORCID: 0000-0001-6665-1533; **Рубаненко Олеся Анатольевна**, доктор медицинских наук, доцент, зав. центром доказательной медицины и статистики, Самарский государственный медицинский университет (г. Самара, Россия), ORCID: 0000-0001-9351-6177; **Трусов Юрий Александрович**, ассистент кафедры пропедевтической терапии с курсом кардиологии, Самарский государственный медицинский университет (г. Самара, Россия), ORCID: 0000-0001-6407-3880; **Колсанов Александр Владимирович**, доктор медицинских наук, профессор, член-корреспондент РАН, ректор, зав. кафедрой оперативной хирургии и топографической анатомии, Самарский государственный медицинский университет (г. Самара, Россия), ORCID: 0000-0002-4144-7090.

### Information about authors

**Garanin Andrey A.**, Cand. of Sci. (Med.), Associate Professor, Director of the Scientific and Practical Center for Remote Medicine, Samara State Medical University (Samara, Russia), ORCID: 0000-0001-6665-1533; **Rubanenko Olesya A.**, Dr. of Sci. (Med.), Associate Professor, Head of the Center for Evidence-based Medicine and Statistics, Samara State Medical University (Samara, Russia), ORCID: 0000-0001-9351-6177; **Trusov Yuri A.**, Assistant Professor at the Department of Propaedeutic Therapy with a Course in Cardiology, Samara State Medical University (Samara, Russia), ORCID: 0000-0001-6407-3880; **Kolsanov Alexander V.**, Dr. of Sci. (Med.), Professor, Corresponding Member of the RAS, Rector, Head of the Department of Operative Surgery and Topographic Anatomy, Samara State Medical University (Samara, Russia), ORCID: 0000-0002-4144-7090.